

DISERTASI

PENGEMBANGAN MODEL *SUPPORT VECTOR MACHINE (SVM)* DAN *GEOSPATIAL ARTIFICIAL INTELLIGENCE (GEOAI)* UNTUK PREDIKSI WILAYAH ENDEMIS DEMAM BERDARAH



Nama : Hetty Meileni
NIM : 03013622227008
BKU : Teknik Informatika
Promotor : Prof. Dr. Ermatita, M.Kom
Ko - Promotor 1 : Dr. Abdiansah, S.Kom., M.CS
Ko - Promotor 2 : Dr. Nyayu Latifah Husni, S.T., M.T

**PROGRAM STUDI DOKTOR ILMU TEKNIK FAKULTAS TEKNIK
UNIVERSITAS SRIWIJAYA
2025**

HALAMAN PENGESAHAN

DISERTASI

(TEK010317)

**PENGEMBANGAN MODEL SUPPORT VECTOR
MACHINE (SVM) DAN GEOSPATIAL ARTIFICIAL
INTELLIGENCE (GEOAI) UNTUK PREDIKSI WILAYAH
ENDEMIS DEMAM BERDARAH**

Oleh:

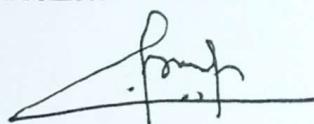
HETTY MEILENI

03013622227008

Telah disetujui

Pada Tanggal 18 Maret 2025

Promotor



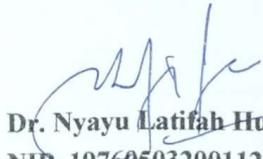
Prof. Dr. Ermatita, M.Kom
NIP.196709132006042001

Ko-Promotor 1



Dr. Abdiansah, S.Kom., M.CS
NIP. 198410012009121005

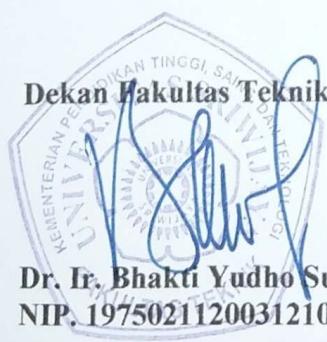
Ko-Promotor 1



Dr. Nyayu Latifah Husni, S.T., M.T.
NIP. 197605032001122002

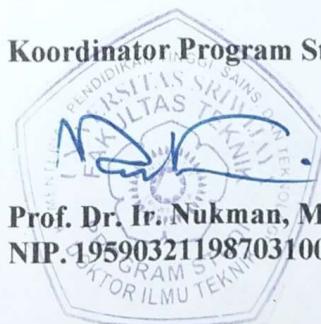
Mengetahui,

Dekan Fakultas Teknik,



Dr. Ir. Bhakti Yudho Suprapto, S.T., M.T., IPM.
NIP. 197502112003121002

Koordinator Program Studi



Prof. Dr. Ir. Nukman, M.T.
NIP. 195903211987031001

HALAMAN PERSETUJUAN

Disertasi berjudul " Pengembangan Model Support *Vector Machine (SVM)* dan *Geospatial Artificial Intelligence (GeoAI)* Untuk Prediksi Wilayah Endemis Demam Berdarah" telah dipresentasikan dihadapan Tim Penguji Disertasi pada Program Studi Doktor Ilmu Teknik Fakultas Teknik Universitas Sriwijaya pada *Rabu, 12 Maret 2025*.

Palembang, 18 Maret 2025

Ditandatangani oleh :

Ketua Tim Penguji:

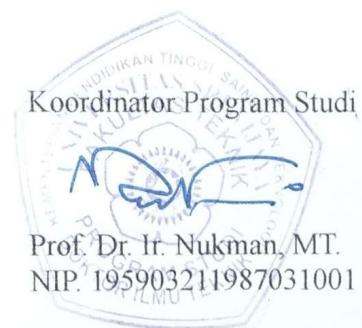
Dr. Ir. Bhakti Yudho Suprapto, S.T., M.T. IPM
NIP. 197502112003121002

()

Anggota Tim Penguji:

1. Dian Palipi Rini, M.Kom., Ph.D
NIP. 197802232006042002
2. Dr. Ali Ibrahim, S.Kom., M.Kom
NIP. 198407212019931004
3. Dr. M. Miftakul Amin, S.Kom., M.Eng
NIP. 197912172012121001

()
()
()



SURAT PERNYATAAN

Saya yang bertanda tangan di bawah ini:

Nama : Hetty Meileni
NIM : 03013622227008
Program Studi : Doktor Ilmu Teknik
BKT : Teknik Informatika

Dengan ini menyatakan bahwa disertasi saya dengan judul “Pengembangan Model *Support Vector Machine (SVM)* dan *Geospatial Artificial Intelligence (GeoAI)* Untuk Prediksi Wilayah Endemis Demam Berdarah”, bebas dari fabrikasi, falsifikasi, plagiat, kepengarangan yang tidak sah dan konflik kepentingan dan pengajuan jamak, seperti yang tercantum dalam Peraturan Menteri Pendidikan, Kebudayaan, Riset, dan Teknologi Republik Indonesia Nomor 39 Tahun 2021.

Bilamana ditemukan ketidak sesuaian dengan hal-hal di atas, maka saya bersedia menerima sanksi akademik dari Universitas Sriwijaya sesuai dengan aturan yang berlaku. Demikian pernyataan ini dibuat dengan sesungguhnya dan dengan sebenar-benarnya.

Palembang, 18 Maret 2025

Yang menyatakan



Hetty Meileni
NIM. 03013622227008

KATA PENGANTAR

Puji dan syukur penulis panjatkan kepada Allah S.W.T atas rahmat dan karunia-Nya sehingga saya dapat menyelesaikan disertasi ini yang berjudul "*Pengembangan Model Support Vector Machine (SVM) dan Geospatial Artificial Intelligence (GeoAI)* untuk Prediksi Wilayah Endemis Demam Berdarah".

Penelitian ini berawal dari keprihatinan penulis terhadap tingginya angka penyebaran demam berdarah di Provinsi Sumatera Selatan dan keinginan untuk berkontribusi dalam upaya penanggulangannya. Melalui pemanfaatan teknologi kecerdasan buatan dan data geospasial, penulis berusaha mengembangkan model prediksi yang dapat membantu pihak terkait dalam mengidentifikasi daerah-daerah yang berpotensi menjadi wilayah endemis.

Perjalanan panjang dalam menyusun disertasi ini melibatkan berbagai tahap, mulai dari pengumpulan dan analisis data, pengembangan model SVM, SVR, GWR dan GeoAI, hingga pengujian dan validasi model. Selama proses tersebut, penulis banyak belajar dan menghadapi berbagai tantangan yang pada akhirnya memperkaya pengetahuan dan pengalaman penulis.

Penulis menyadari bahwa penyelesaian disertasi ini tidak lepas dari bantuan dan dukungan berbagai pihak. Oleh karena itu, dengan segala kerendahan hati, penulis ingin menyampaikan terima kasih yang sebesar-besarnya kepada:

1. Prof. Dr. Ermatita, M.Kom, selaku Promotor, yang dengan sangat sabar membimbing, memotivasi dan memberikan arahan berharga sepanjang proses penelitian ini.
2. Dr. Abdiansah, S.Kom., M.CS, sebagai Ko-Promotor 1, atas bimbingannya, dukungan, dan saran yang sangat membantu dalam penyempurnaan disertasi ini.
3. Dr. Nyayu Latifah Husni, S.T., M.T, sebagai Ko-Promotor 2, yang telah memberikan arahan, dukungan serta motivasi dalam penyusunan disertasi ini.
4. Prof Dr. Ir. Nukman, M.T, selaku Koordinator Program Studi Program Doktor Ilmu Teknik, yang telah memberikan dukungan, fasilitas, arahan serta tak henti-hentinya memberikan semangat kepada penulis sehingga penulis dapat menyelesaikan penulisan laporan disertasi ini.

5. Dr. Ing. Ahmad Taqwa, M.T, selaku Direktur Politeknik Negeri Sriwijaya periode 2016-2020 dan 2020-2024 yang telah memberikan bantuan, dukungan, serta fasilitas dalam penyelesaian laporan disertasi ini.
6. Ir. Irawan Rusnadi, M.T, selaku Direktur Politeknik Negeri Sriwijaya periode 2024-2028 yang telah memberikan bantuan, dukungan dan fasilitas sehingga penulis dapat menyelesaikan laporan disertasi ini.
7. Seluruh dosen di Prodi Ilmu Teknik yang telah membagikan ilmu, wawasan, dan pengalaman berharga selama masa perkuliahan.
8. Rekan-rekan sejawat, teman teman sekelas (Leni, Yurni, Lily, Kak Fery, Kak Alan, Kak Azwardi, Haviz dan Fadzri) yang telah memberikan dukungan, bantuan moril, mendoakan dengan tulus serta terus memotivasi penulis sehingga Studi S3 ini berjalan dengan lancar.
9. Seluruh staff di Prodi Ilmu Teknik (Mbk Yuni, Aang dan Gilang), yang telah memberikan bantuan teknis dan moral selama penelitian ini berlangsung.
10. Keluarga tercinta, yang selalu memberikan doa, semangat, dan motivasi tanpa henti.

Disertasi ini telah menghasilkan beberapa capaian penting, antara lain publikasi dalam prosiding konferensi ilmiah dan penerbitan artikel di jurnal internasional bereputasi serta penerbitan buku cetak. Saya berharap kontribusi ini dapat memberikan manfaat nyata bagi perkembangan ilmu pengetahuan dan upaya pengendalian demam berdarah di Provinsi Sumatera Selatan.

Akhir kata, penulis menyadari bahwa disertasi ini masih jauh dari sempurna. Oleh karena itu, kritik dan saran yang membangun sangat diharapkan untuk perbaikan di masa yang akan datang. Semoga disertasi ini tidak hanya menjadi karya akademik, tetapi juga memberi kontribusi bagi kemajuan ilmu pengetahuan dan membawa manfaat bagi siapa saja yang membacanya.

Palembang, Maret 2025

Penulis

RINGKASAN

Penelitian ini mengembangkan model prediktif untuk mengidentifikasi wilayah endemis Demam Berdarah Dengue (DBD) dengan mengintegrasikan *Support Vector Machine (SVM)*, *Support Vector Regression (SVR)*, *Geographically Weighted Regression (GWR)*, dan *Geospatial Artificial Intelligence (GeoAI)*. Data epidemiologi DBD periode 2017–2023 digunakan, mencakup jumlah kasus DBD, kepadatan penduduk, variabel iklim (suhu, curah hujan, kelembaban), serta data spasial tiap Kabupaten/Kota dan Kecamatan. Penelitian ini terdiri dari tiga tahap utama: (1) klasifikasi wilayah endemis dan non-endemis menggunakan SVM, (2) prediksi jumlah kasus DBD menggunakan SVR, dan (3) analisis hubungan spasial dengan GWR. Evaluasi model dilakukan menggunakan metrik akurasi, *Mean Absolute Error (MAE)*, *Mean Squared Error (MSE)*, *Root Mean Square Error (RMSE)*, *Mean Absolute Percentage Error (MAPE)* serta peta spasial berbasis GeoAI. Hasil penelitian menunjukkan bahwa SVM mampu mengklasifikasikan wilayah endemis DBD dengan akurasi 99.12%, dengan *Precision* 98.3%, *Recall* 96.6%, dan *F1-Score* 99.44%. Model SVR dengan kernel Linear menghasilkan MAE 0.096, MSE 0.009, RMSE 0.097, dan MAPE 30.79%, menunjukkan tingkat akurasi prediksi yang baik. Sementara itu, GWR dengan kernel *Bi-Square* lebih akurat dalam menangkap pola spasial DBD dibandingkan metode RBF, sebagaimana ditunjukkan oleh nilai *Moran's I* sebesar 0.00131 dan AIC 150.04857. Penelitian ini memberikan kontribusi signifikan terhadap pengembangan sistem peringatan dini yang lebih akurat untuk penanggulangan DBD, yang dapat mendukung pengambilan keputusan strategis, seperti penyebaran tenaga medis, alokasi perlengkapan medis, serta pelaksanaan sosialisasi pencegahan yang lebih terarah. Secara keseluruhan, hasil penelitian ini membuktikan bahwa integrasi antara SVM, SVR, dan GeoAI dapat menghasilkan model prediktif yang efektif dalam memetakan dan menganalisis wilayah endemis DBD, meningkatkan akurasi prediksi, serta menyediakan dasar yang kuat untuk strategi pengendalian penyakit menular di Provinsi Sumatera Selatan.

Kata kunci: Demam Berdarah Dengue (DBD), *Support Vector Machine (SVM)*, *Support Vector Regression (SVR)*, *Geographically Weighted Regression (GWR)*, *GeoAI*, prediksi wilayah endemis, pemodelan spasial.

SUMMARY

This study uses Support Vector Machine (SVM), Support Vector Regression (SVR), Geographically Weighted Regression (GWR), and Geospatial Artificial Intelligence (GeoAI) to make a model that can predict where Dengue Fever (DF) is most likely to happen. The study utilizes DHF epidemiological data from 2017 to 2023, which included the number of DF cases, population density, climatic variables (temperature, rainfall, and humidity), and spatial data from each city and sub-city. This study has three main parts: (1) using SVM to sort areas into endemic and non-endemic groups; (2) using SVR to guess the number of DF cases; and (3) using GWR to look at spatial relationships. We checked the model's accuracy with Mean Absolute Error (MAE), Mean Squared Error (MSE), Root Mean Square Error (RMSE), Mean Absolute Percentage Error (MAPE) and GeoAI-based spatial mapping. With a 98.3% accuracy rate, a 96.6% recall rate, and an F1 score of 99.44%, SVM was able to correctly identify DF-endemic areas 99.12% of the time. The linear kernel in the SVR model gave an MAE of 0.096, an MSE of 0.009, an RMSE of 0.097, and a MAPE of 30.79%, showing that it was very good at predicting the future. The Moran's I value of 0.00131 and the AIC value of 150.04857 show that GWR with the Bi-Square kernel was better than the RBF method at capturing the spatial patterns of DF. This study is a big step toward making a better early warning system for DF control. This will help with making strategic decisions like where to send medical staff, how to use resources, and how to target public awareness campaigns. Overall, this study shows that combining SVM, SVR, and GeoAI can make a good predictive model for mapping and analyzing areas where dengue fever is common. This improves the accuracy of predictions and builds a strong base for South Sumatra Province's plans to control infectious diseases.

Keywords: Dengue Fever (DF), Support Vector Machine (SVM), Support Vector Regression (SVR), Geographically Weighted Regression (GWR), GeoAI, endemic area prediction, spatial modeling.

DAFTAR ISI

DISERTASI	i
HALAMAN PENGESAHAN	ii
HALAMAN PERSETUJUAN	iii
SURAT PERNYATAAN	iv
KATA PENGANTAR	v
RINGKASAN	vii
SUMMARY	viii
DAFTAR GAMBAR	xii
DAFTAR TABEL	xv
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	4
1.3 Tujuan Penelitian	5
1.4 Batasan Masalah	5
1.5 Kebaruan dan Kontribusi Penelitian	6
1.6 Manfaat Penelitian	6
1.7 Sistematika Laporan Disertasi	6
BAB II TINJAUAN PUSTAKA	8
2.1 Demam Berdarah Dengue (DBD)	8
2.2 <i>Support Vector Machine (SVM)</i>	9
2.3 Pelatihan SVM	12
2.4 <i>Support Vector Regression (SVR)</i>	14
2.4.1 Fungsi SVR	16
2.5.1 Estimasi parameter dalam GWR	20
2.5.2 Penjelasan Perhitungan Bobot dengan Kernel <i>Bi-Square</i>	21
2.6 <i>Geospatial Artificial Intelligence (GeoAI)</i>	22
2.7 Integrasi SVM, SVR, dan GeoAI	25
2.8 Metode Pengujian	26
2.8.1 <i>Confusion Matrix</i>	26
2.8.2 F-Measure	27
2.8.3 <i>Mean Absolute Error (MAE)</i>	29
2.8.4 <i>Mean Square Error (MSE)</i>	29
2.8.5 <i>Root Mean Square Error (RMSE)</i>	30
2.8.6 <i>Mean Absolute Percentage Error (MAPE)</i>	30

2.9	Penelitian terdahulu	31
2.10	Bahasa Pemrograman <i>Python</i>	34
BAB III METODOLOGI PENELITIAN		37
3.1	Desain Penelitian	37
3.2	Sumber Data	42
3.3	Pengumpulan Data.....	42
	3.3.1 Data Epidemiologi	43
3.3.2	Data Iklim	44
	3.3.3 Data Spasial	44
	3.3.4 Data Penduduk.....	45
3.4	Data Set	46
3.5	Pemrosesan Data (<i>Data Processing</i>) dengan Phyton	47
3.6	Visualisasi Data	49
	3.6.1 Visualiasi DBD	49
	3.6.2 Visualisasi Data Iklim.....	55
	3.6.3 Visualisasi Data Kepadatan Penduduk	56
BAB IV HASIL DAN PEMBAHASAN		60
4.1	Hasil.....	60
	4.1.1 Korelasi Data	60
	4.1.2 Korelasi Pada Kecamatan Banyuasin III	61
	4.1.3 Korelasi Pada Kecamatan Tebing Tinggi.....	62
	4.1.4 Korelasi Pada Kecamatan Merapi Timur.....	63
	4.1.5 Korelasi Pada Kecamatan Bayung Lencir	65
	4.1.6 Korelasi Pada Kecamatan Tugumulyo.....	66
	4.1.7 Korelasi Pada Kecamatan Nibung	67
	4.1.8 Korelasi Pada Kecamatan Kayuagung.....	69
	4.1.9 Korelasi Pada Kecamatan Baturaja Timur.....	71
	4.1.10 Korelasi Pada Kecamatan Muaradua	72
	4.1.11 Korelasi Pada Kecamatan Martapura	74
	4.1.12 Korelasi Pada Kecamatan Indralaya	75
	4.1.13 Korelasi Pada Kecamatan Talang Ubi	77
	4.1.14 Korelasi Pada Kecamatan Pagaralam Selatan	78
	4.1.15 Korelasi Pada Kecamatan Sukarami.....	79
	4.1.16 Korelasi Pada Kecamatan Prabumulih Timur.....	81
	4.1.17 Korelasi Pada Kecamatan Lubuk Linggau Timur 1	83
	4.1.18 Korelasi Data Tahunan.....	84

4.2	Pembahasan	86
4.2.1	Pemodelan <i>Support Vector Machine (SVM)</i>	86
4.2.2	Hasil Penerapan Metode <i>Support Vector Regression (SVR)</i> ...	100
4.2.3	SVR Penderita DBD	105
4.2.4	SVR Kematian DBD.....	133
4.2.5	Pemodelan <i>Geographically Weighted Regression (GWR)</i>	156
4.2.6	Implementasi GeoAI untuk Prediksi Wilayah Endemis Demam Berdarah Dengue Menggunakan Model SVM, SVR, dan GWR	184
4.3	Kesimpulan Analisis Data	195
BAB V	PENUTUP	197
5.1.	Kesimpulan.....	197
5.2	Rekomendasi	198
	DAFTAR PUSTAKA	200

LAMPIRAN SURAT KETERANGAN PERBAIKAN DISERTASI

SEMINAR KARYA ILMIAH

LAMPIRAN PUBLIKASI INTERNASIONAL 1

LAMPIRAN PUBLIKASI INTERNASIONAL 2

LAMPIRAN BUKU CETAK

LAMPIRAN SURAT RISET DAN EXPERT JUDGEMENT

LAMPIRAN DAFTAR TABEL

DAFTAR GAMBAR

2.1	Confusion Matrix.....	27
3.1	Desain penelitian.....	39
3.2	Tahapan-Tahapan Penelitian.....	41
3.3	Kasus DBD Setiap Kabupaten Periode 2017-2023.....	50
3.4	Kasus DBD Provinsi Sumatera Selatan 2017-2023.....	52
3.5	Total Kasus DBD Per Kabupaten Periode 2017-2023.....	53
3.6	Kasus DBD Tertinggi di Kecamatan	54
3.7	Perbandingan Kasus DBD dan Kematian	55
3.8	Perbandingan Data Iklim.....	56
3.9	Kepadatan Penduduk Periode 2017-2023.....	57
3.10	<i>Heatmap</i> Kepadatan Penduduk	58
3.11	Kecamatan dengan Kepadatan Tertinggi	59
4.1	Korelasi Pada Kecamatan Banyuasin III	61
4.2	Korelasi Pada Kecamatan Tebing Tinggi	63
4.3	Korelasi Pada Kecamatan Merapi Timur	64
4.4	Korelasi Pada Kecamatan Bayung Lencir	65
4.5	Korelasi Pada Kecamatan Tugumulyo	67
4.6	Korelasi Pada Kecamatan Nibung	69
4.7	Korelasi Pada Kecamatan Kayuagung	70
4.8	Korelasi Pada Kecamatan Baturaja Timur	72
4.9	Korelasi Pada Kecamatan Muaradua	73
4.10	Korelasi Pada Kecamatan Martapura	75
4.11	Korelasi Pada Kecamatan Indralaya	76
4.12	Korelasi Pada Kecamatan Talang Ubi	78
4.13	Korelasi Pada Kecamatan Pagaralam Selatan	79
4.14	Korelasi Pada Kecamatan Sukarami	81
4.15	Korelasi Pada Kecamatan Prabumulih Timur	82
4.16	Korelasi Pada Kecamatan Lubuk Linggau Timur I.....	84
4.17	Perbandingan Korelasi tahunan di Provinsi Sumatera Selatan	85
4.18	Confusion Matrix	97
4.19	Hasil Prediksi Pada Kecamatan Banyuasin III	106
4.20	Hasil Prediksi Pada Kecamatan Tebing Tinggi	109
4.21	SVR Pada Kecamatan Merapi Timur	111
4.22	Hasil Prediksi Pada Kecamatan Bayung Lencir	113
4.23	Hasil Prediksi Pada Kecamatan Tugu Mulyo	116
4.24	Hasil Prediksi Pada Kecamatan Nibung	118
4.25	Hasil Prediksi Pada Kecamatan Kayuagung	120
4.26	Hasil Prediksi Pada Kecamatan Talang Ubi	122
4.27	Hasil Prediksi Pada Kecamatan Pagar Alam Selatan	124
4.28	Hasil Prediksi Pada Kecamatan Sukarami	127
4.29	Hasil Prediksi Pada Kecamatan Prabumulih Timur	130
4.29	Hasil Prediksi Pada Kecamatan Lubuk Linggau Timur I	131
4.30	SVR Kematian Pada Kecamatan Banyuasin III	134

4.31	SVR Kematian Pada Kecamatan Tebing Tinggi	136
4.32	SVR Kematian Pada Kecamatan Merapi Timur	138
4.33	SVR Kematian Pada Kecamatan Bayung Lencir.....	140
4.34	SVR Kematian Pada Kecamatan Tugu Mulyo	122
4.35	SVR Kematian Pada Kecamatan Nibung.....	144
4.36	SVR Kematian Pada Kecamatan Kayu Agung.....	146
4.37	SVR Kematian Pada Kecamatan Talang Ubi	148
4.38	SVR Kematian Pada Kecamatan Pagar Alam Selatan	149
4.39	SVR Kematian Pada Kecamatan Sukarami	151
4.40	SVR Kematian Pada Kecamatan Prabumulih Timur	153
4.41	SVR Kematian Pada Kecamatan Lubuk Linggau Timur 1	155
4.42	Matrix Diagonal	165
4.43	Perbandingan Koefisien Variabel Pada Model GWR Di Kecamatan Musi Rawa Kernel Bo square dan RBF	165
4.44	Perbandingan Koefisien Variabel pada Model GWR Kematian DBD di Kabupaten Banyuasin Menggunakan Kernel <i>Bi-Square</i> dan RBF ...	165
4.45	Perbandingan Koefisien Variabel pada Model GWR di Kecamatan Musi Rawas Utara Menggunakan Kernel <i>Bi-Square</i> dan RBF	166
4.46	Perbandingan Koefisien Variabel Kematian DBD pada Model GWR di Kecamatan Musi Rawas Utara Menggunakan Kernel <i>Bi-Square</i> dan RBF	166
4.47	Perbandingan Nilai Kepadatan Antara Model Bi-Square dan RBF Untuk Analisis Kematian	172
4.48	Perbandingan Nilai Kelembaban Antara Model Bi-Square dan RBF Untuk Analisis Kematian DBD	172
4.49	Perbandingan Nilai Hujan Antara Model Bi-Square dan RBF Untuk Analisis Kematian DBD.....	173
4.50	Perbandingan Nilai Suhu Antara Model Bi-Square dan RBF Untuk Analisis Kematian DBD	173
4.51	Perbandingan Nilai Kelembaban Antara Model Bi-Square dan RBF Untuk Analisis Kasus DBD Pada Kabupaten Musi Rawas Utara	172
4.52	Perbandingan Nilai Kepadatan Antara Model Bi-Square dan RBF Untuk Analisis Kasus DBD Pada Kabupaten Musi Rawas Utara	176
4.53	Perbandingan Nilai Curah Hujan Antara Model Bi-Square dan RBF Untuk Analisis Kasus DBD Pada Kabupaten Musi Rawas Utara	177
4.54	Perbandingan Nilai Suhu Antara Model Bi-Square dan RBF Untuk Analisis Kasus DBD Pada Kabupaten Musi Rawas Utara	177
4.55	Perbandingan Nilai Kelembaban Antara Model Bi-Square dan RBF Untuk Analisis Kematian DBD Pada Kabupaten Musi Rawas Utara	181
4.56	Perbandingan Nilai Kepadatan Antara Model Bi-Square dan RBF Untuk Analisis Kematian DBD Pada Kabupaten Musi Rawas Utara	181
4.57	Perbandingan Nilai Hujan Antara Model Bi-Square dan RBF Untuk Analisis Kematian DBD Pada Kabupaten Musi Rawas Utara	182
4.58	Perbandingan Nilai Kelembaban Antara Model Bi-Square dan RBF Untuk Analisis Kematian DBD Pada Kabupaten Musi Rawas Utara	182
4.59	Halaman Awal Sistem	185
4.60	Halaman Tambah User	186

4.61	Tampilan Daftar Kabupaten dan Kecamatan	187
4.62	Tampilan Daftar Kabupaten dan Kecamatan	187
4.63	Tampilan Daftar Kabupaten dan Kecamatan	188
4.64	Tampilan Daftar Kabupaten dan Kecamatan	188
4.65	Tampilan Halaman Kelola Data Kabupaten	189
4.66	Tampilan Halaman Daftar Kabupaten	189
4.67	Tampilan Halaman Kelola Data Kecamatan	190
4.68	Tampilan Halaman Daftar Kecamatan	191
4.69	Tampilan Halaman Kelola Data Parameter Lingkungan dan DBD.....	192
4.70	Tampilan Halaman Peta Wilayah Endemis DBD	193
4.71	Tampilan Halaman Peta Wilayah Endemis DBD	194

DAFTAR TABEL

2.1	Penelitian Terdahulu.....	31
4.1	Klasifikasi Wilayah Endemi.....	94
4.2	Hasil Evaluasi Kinerja Model SVR Kecamatan Banyuasin III.....	107
4.3	Hasil Evaluasi Kinerja Model SVR Kecamatan Tebing Tinggi	110
4.4	Hasil Evaluasi Kinerja Model SVR Kecamatan Merapi Timur	112
4.5	Hasil Evaluasi Kinerja Model SVR Kecamatan Bayung Lencir	114
4.6	Hasil Evaluasi Kinerja Model SVR Kecamatan Tugu Mulyo	117
4.7	Hasil Evaluasi Kinerja Model SVR Kecamatan Nibung	119
4.8	Hasil Evaluasi Kinerja Model SVR Kecamatan Kayuagung	121
4.9	Hasil Evaluasi Kinerja Model SVR Kecamatan Talang Ubi	123
4.10	Hasil Evaluasi Kinerja Model SVR Kecamatan Pagar Alam Selatan	126
4.11	Hasil Evaluasi Kinerja Model SVR Kecamatan Sukarami	128
4.12	Hasil Evaluasi Kinerja Model SVR Kecamatan Lubuk Linggau Timur 1	132
4.13	Evaluasi Model SVR Kematian DBD Pada Kecamatan Banyuasin III ..	134
4.14	Evaluasi Model SVR Kematian DBD Pada Kecamatan Tebing Tinggi	136
4.15	Evaluasi Model SVR Kematian DBD Pada Kecamatan Merapi Timur	138
4.16	Evaluasi Model SVR Kematian DBD Pada Kecamatan Bayung Lencir	140
4.17	Evaluasi Model SVR Kematian DBD Pada Kecamatan Tugu Mulyo	142
4.18	Evaluasi Model SVR Kematian DBD Pada Kecamatan Nibung	144
4.19	Evaluasi Model SVR Kematian DBD Pada Kecamatan Kayu Agung...	146
4.20	Evaluasi Model SVR Kematian DBD Pada Kecamatan Talang Ubi	148
4.21	Evaluasi Model SVR Kematian DBD Pada Kecamatan Pagar Alam Selatan	150
4.22	Evaluasi Model SVR Kematian DBD Pada Kecamatan Sukarami	152
4.23	Evaluasi Model SVR Kematian DBD Pada Kecamatan Prabumulih Timur.....	153
4.24	Evaluasi Model SVR Kematian DBD Pada Kecamatan Lubuk Linggau Timur 1	155
4.25	Koordinat Geografis	156
4.26	Variabel Lingkungan, Kepadatan Penduduk dan Kasus DBD.....	157
4.27	Data Lingkungan	158
4.28	Hasil Scaler	158
4.29	Matrix Jarak Lokasi 1 Terhadap Seluruh Lokasi	159
4.30	Hasil Perhitungan Bobot	161
4.31	Koeffisien Untuk Data Pertama	162
4.32	Koeffisien Regresi Penderita DBD Menggunakan Metode RBF Pada Kabupaten Banyuasin	163
4.33	Koeffisien Regresi Penderita DBD Menggunakan Metode <i>Bi-Square</i> Pada Kabupaten Banyuasin	164

4.34	Perbandingan Kinerja Model GWR Dengan Kernel Bisquare dan RBF Berdasarkan Metrik Evaluasi di Kabupaten Banyuasin	169
4.35	Perbandingan Nilai Moran's I dan AIC Pada Model GWR Dengan Kernel <i>Bi-Square</i> dan RBF Penderita DBD di Kabupaten Banyuasin	170
4.36	Koefisien Regresi Kematian DBD Menggunakan Metode RBF Pada Kabupaten Banyuasin	170
4.37	Koefisien Regresi Kematian DBD Menggunakan Metode <i>Bi-Square</i> Pada Kabupaten Banyuasin	171
4.38	Perbandingan Kinerja Model GWR Dengan Kernel Bisquare dan RBF Berdasarkan Metrik Evaluasi Kematian DBD di Kabupaten Banyuasin	175
4.39	Perbandingan Nilai Moran's I dan AIC Pada Model GWR Dengan Kernel <i>Bi-Square</i> dan RBF Kematian DBD di Kabupaten Banyuasin	175
4.40	Perbandingan Kinerja Model GWR dengan Kernel <i>Bi-Square</i> dan RBF Berdasarkan Metrik Evaluasi di Kabupaten Musi Rawas Utara	178
4.41	Perbandingan Nilai Moran's I dan AIC pada Model GWR dengan Kernel <i>Bi-Square</i> dan RBF di Kecamatan Musi Rawas Utara	179
4.42	Koefisien Regresi Kematian DBD Menggunakan Metode <i>Bi-Square</i> Pada Kabupaten Musi Rawas Utara	180
4.43	Koefisien Regresi Kematian DBD Menggunakan Metode RBF Pada Kabupaten Musi Rawas Utara	180
4.44	Perbandingan Kinerja Model GWR dengan Kernel <i>Bi-Square</i> dan RBF Berdasarkan Metrik Evaluasi Kematian DBD di Kabupaten Musi Rawas Utara	183
4.45	Perbandingan Nilai Moran's I dan AIC pada Model GWR dengan Kernel <i>Bi-Square</i> dan RBF Kematian DBD di Kabupaten Musi Rawas Utara	184

BAB I PENDAHULUAN

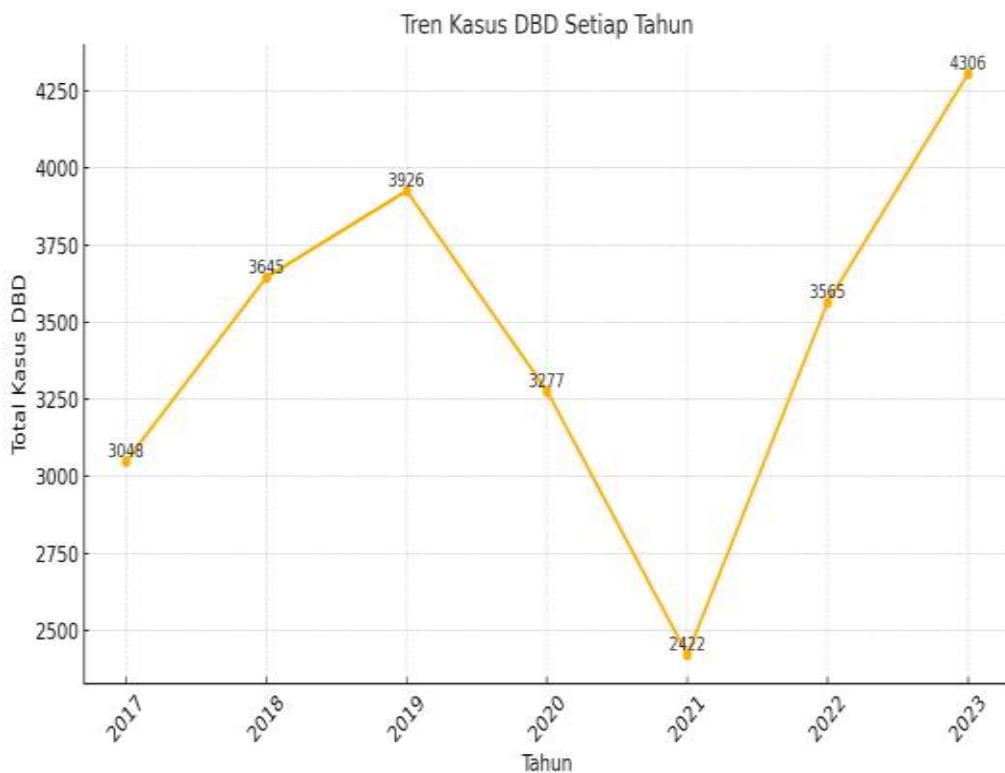
1.1 Latar Belakang

Demam Berdarah Dengue (DBD) adalah salah satu isu kesehatan masyarakat global, ditandai oleh gejala seperti demam tinggi, sakit kepala hebat, nyeri di belakang mata, nyeri pada sendi dan otot, ruam kulit, serta perdarahan ringan seperti mimisan atau gusi berdarah [1]. Pada kasus yang lebih serius, DBD dapat berkembang menjadi sindrom dengue atau syok dengue, yang menyebabkan perdarahan berat, penurunan tekanan darah secara mendadak, dan berpotensi mengakibatkan kematian [2]. Penyakit ini disebabkan oleh virus dengue yang menyebar kepada manusia melalui gigitan nyamuk Aedes yang terinfeksi [3].

Pengaruh demam berdarah tidak hanya mempengaruhi kesehatan individu, tetapi juga membawa konsekuensi ekonomi dan sosial. Wabah demam berdarah dapat memberikan tekanan pada sistem kesehatan, khususnya di daerah yang endemik, yang mengakibatkan peningkatan jumlah pasien rawat inap dan biaya pengobatan [4]. Selain itu, wabah ini juga dapat merugikan sektor pariwisata, seperti yang terlihat dalam penelitian tentang efek kedatangan wisatawan internasional terhadap pertumbuhan ekonomi di tengah risiko demam berdarah di Malaysia [5].

Berdasarkan data yang dikeluarkan oleh Kementerian Kesehatan RI tahun 2023, angka kesakitan DBD cenderung fluktuatif dalam rentang waktu 2013 hingga 2023. Pada tahun 2023 terdapat 114.720 kasus DBD dengan jumlah kematian sebanyak 894 kasus. Kasus maupun kematian akibat DBD mengalami penurunan dibandingkan tahun 2022 yaitu sebesar 143.266 kasus dan 1.237 kematian.

Kasus DBD di Provinsi Sumatera Selatan mengalami peningkatan yang signifikan antara tahun 2017 dan 2023. Pada Gambar 1.1 menunjukkan bahwa tahun 2023 merupakan tahun dengan jumlah kasus DBD tertinggi, mencapai 4.306 kasus.



Gambar 1.1 Tren Kasus DBD Provinsi Sumatera Selatan

Mengingat tingginya angka kejadian DBD, penting untuk melakukan prediksi dini terhadap wilayah endemis guna memungkinkan respons yang cepat dan tepat, seperti penambahan tenaga medis, penyediaan perlengkapan medis yang diperlukan, serta peningkatan pengawasan dan pemantauan terhadap vektor DBD. Untuk mengendalikan dan mencegah penyebaran DBD, berbagai langkah telah diimplementasikan, termasuk penggunaan pemodelan spasial untuk mengidentifikasi wilayah endemis DBD.

Penduduk Provinsi Sumatera Selatan tahun 2022 berdasarkan hasil Proyeksi Penduduk Interim 2020-2023 sebanyak 8,66 juta jiwa. Kepadatan penduduk di Provinsi Sumatera Selatan tahun 2022 mencapai 99,77 jiwa/km² juta, memiliki karakteristik geografis dan iklim yang berpotensi mendukung penyebaran DBD. Wilayah ini sebagian besar merupakan dataran rendah dengan ketinggian rata-rata 97 meter di atas permukaan laut, serta memiliki curah hujan tinggi mencapai 3.250,2 mm per tahun dengan suhu rata-rata 29,4°C [10].

Support vector Machine (SVM) telah banyak digunakan dalam penelitian prediksi penyakit menular karena kemampuannya dalam mengkalsifikasikan data secara akurat berdasarkan fitur-fitur yang relevan. SVM mampu mengidentifikasi wilayah endemis dan non endemis berdasarkan variabel lingkungan dan epidemiologi. Namun, untuk prediksi jumlah kasus DBD secara kuantitatif, diperlukan metode regresi yang lebih tepat. Oleh karena itu, *Support Vector Regression (SVR)* digunakan sebagai pendekatan untuk memprediksi jumlah kasus DBD dengan mempertimbangkan berbagai faktor yang berkorelasi terhadap pola persebaran penyakit. Untuk memahami lebih dalam hubungan antara variabel lingkungan dan kejadian DBD secara spasial, *Geographically Weighted Regression (GWR)* diterapkan untuk menganalisis hubungan antara faktor lingkungan, seperti curah hujan, suhu, dan kelembaban dengan kejadian DBD dapat bervariasi antar wilayah.

SVR merupakan pengembangan dari SVM yang difokuskan pada pemodelan data regresi. Dengan menggunakan fungsi kernel, SVR dapat menangkap pola hubungan non linear yang kompleks. Kombinasi SVM, SVR, GWR dan teknik *Geospatial Artificial Intelligence (GeoAI)* memungkinkan pemetaan prediktif berbasis spasial yang lebih rinci, sehingga menghasilkan model yang lebih efektif.

Banyak penelitian telah dilakukan untuk memprediksi dan memahami pola penyebaran demam berdarah di berbagai wilayah. Penelitian yang dilakukan Adde et al [6] menekankan pentingnya variabel iklim dalam memprediksi wabah demam berdarah di Guyana Prancis dengan menggunakan indikator iklim untuk menentukan tahun-tahun epidemi. Tian et al. [7] mengaplikasikan metode ARIMA untuk memprediksi tren insidensi demam berdarah di wilayah-wilayah endemik utama. Studi-studi ini menggarisbawahi peran penting faktor lingkungan dalam meramalkan wabah demam berdarah.

Selain itu, penelitian Acharya et al [8] mengeksplorasi prospek demam berdarah di Nepal, menunjukkan peningkatan signifikan dalam populasi yang rentan terhadap penyakit ini, yang menuntut tindakan pencegahan yang lebih proaktif. Penelitian oleh Sahan et al [9] dan Pereira et al [10] juga menyoroti perlunya kewaspadaan tinggi dalam mengenali dan mengatasi demam berdarah di daerah endemik dengan prevalensi tinggi.

Salim et al. [11] menunjukkan bahwa SVM dengan kernel linear dapat memprediksi wabah demam berdarah tanpa *Overfitting*. Hal ini menunjukkan potensi SVM dalam memprediksi penyebaran demam berdarah. Selain itu, penelitian oleh Halim et al. [12] juga menggunakan pendekatan neural network untuk memodelkan wabah demam berdarah, menunjukkan variasi dalam pendekatan *machine learning* yang dapat digunakan untuk tujuan prediksi. Namun, terdapat kesenjangan penelitian yang dapat diidentifikasi dari penelitian-penelitian tersebut. Salah satunya adalah kebutuhan untuk integrasi yang lebih mendalam antara teknik *Machine Learning* seperti SVM, SVR dan GeoAI dalam memprediksi penyebaran demam berdarah. Meskipun beberapa penelitian telah menggunakan SVM untuk memprediksi wabah demam berdarah dan beberapa telah memanfaatkan GeoAI untuk pemodelan spasial, masih ada ruang untuk menggabungkan kedua pendekatan ini secara lebih terperinci. Penelitian masa depan dapat fokus pada pengembangan model yang menggabungkan model SVM, SVR dan GWR dalam prediksi dengan kemampuan GeoAI dalam analisis spasial untuk meningkatkan akurasi dan ketepatan prediksi wilayah endemis demam berdarah.

Dengan mempertimbangkan hal-hal tersebut, pengembangan model prediksi berbasis SVM, SVR, GWR dengan memanfaatkan GeoAI untuk wilayah endemis DBD di Provinsi Sumatera Selatan sangatlah penting. Model ini akan memanfaatkan data geospasial yang mencakup informasi wilayah, kepadatan penduduk, data suhu, data kelembaban, data curah hujan, serta data kasus DBD. Dengan bantuan SVM dan SVR model ini dapat mengklasifikasikan wilayah menjadi endemis atau non-endemis. Diharapkan, pengembangan model ini dapat memberikan kontribusi yang signifikan dalam prediksi dan pencegahan penyebaran DBD di masa depan, serta memperkuat upaya pengendalian penyakit ini.

1.2 Rumusan Masalah

Beberapa teknik sudah dikembangkan untuk memprediksi penyakit demam berdarah, akan tetapi penelitian yang membahas pengembangan model SVM, SVR, GWR, dan GeoAI untuk prediksi wilayah endemis demam berdarah masih terbatas.

Untuk itu pertanyaan riset yang akan dijawab pada penelitian ini adalah:

1. Bagaimana klasifikasi wilayah endemis demam berdarah menggunakan SVM?
2. Bagaimana estimasi jumlah kasus DBD menggunakan SVR?
3. Bagaimana analisis spasial menggunakan GWR untuk memahami variabel lingkungan dengan kejadian DBD?
4. Bagaimana melakukan penilaian dan evaluasi akurasi model prediksi yang dihasilkan?

1.3 Tujuan Penelitian

Tujuan penelitian ini adalah:

1. Mengembangkan mode klasifikasi wilayah endemis DBD menggunakan metode SVM.
2. Memprediksi jumlah kasus DBD menggunakan metode SVR.
3. Menganalisis hubungan spasial antara variabel lingkungan dan kejadian DBD menggunakan GWR.
4. Melakukan penilaian dan evaluasi tingkat akurasi model prediksi yang dihasilkan melalui validasi dan analisis data empiris.

1.4 Batasan Masalah

Berikut ini beberapa batasan penelitian yang ditentukan:

1. Data yang digunakan dalam penelitian ini dibatasi pada wilayah Provinsi Sumatera Selatan, khususnya daerah-daerah yang telah teridentifikasi mengalami kasus DBD.
2. Parameter yang digunakan untuk prediksi terbatas pada faktor-faktor yang berpengaruh signifikan terhadap penyebaran DBD, yaitu kepadatan penduduk, kelembaban, suhu, curah hujan, jumlah penderita DBD, dan angka kematian akibat DBD.
3. Penelitian ini difokuskan pada pengembangan model prediksi menggunakan metode SVM untuk klasifikasi wilayah, SVR untuk estimasi jumlah kasus DBD, GWR untuk analisis hubungan spasial dan GeoAI untuk visualisasi pemetaan wilayah endemis DBD.

1.5 Kebaruan dan Kontribusi Penelitian

Penelitian ini mengembangkan model prediksi wilayah endemis Demam Berdarah Dengue (DBD) dengan mengintegrasikan metode SVM, SVR, GWR dan GeoAI. Pendekatan ini memberikan kontribusi metodologis dengan memanfaatkan kombinasi model klasifikasi, regresi, dan analisis spasial guna meningkatkan akurasi prediksi. Dengan menerapkan pendekatan ini, penelitian ini berkontribusi pada pengembangan sistem peringatan dini yang lebih akurat untuk mitigasi DBD serta dapat diadaptasi untuk pemodelan penyakit menular lainnya.

1.6 Manfaat Penelitian

Penelitian ini memberikan manfaat akademik dan praktis, antara lain :

1. Meningkatkan akurasi prediksi wilayah endemis DBD melalui pendekatan pembelajaran mesin berbasis SVM dan SVR yang terintegrasi dengan GeoAI.
2. Memberikan kontribusi dalam pengembangan sistem pemantauan dan peringatan dini berbasis kecerdasan buatan untuk pengendalian DBD.
3. Mendukung perencanaan strategis alokasi sumber daya kesehatan dengan memanfaatkan analisis spasial berbasis GeoAI.

1.7 Sistematika Laporan Disertasi

Sistematika laporan disertasi ini terdiri dari lima Bab, yang pertama pendahuluan, kemudian secara berurutan, landasan teori, dan metodologi penelitian, Hasil dan Pembahasan, Penutup

BAB I. PENDAHULUAN

Bab I berisi latar belakang permasalahan yang akan diteliti. Kemudian merumuskan latar belakang dalam bentuk pertanyaan penelitian. Dalam bab ini juga disampaikan tujuan dan manfaat penelitian yang ingin dicapai.

BAB II. TINJAUAN PUSTAKA

Dalam Bab ini disampaikan penelitian dan publikasi terkait pengembangan model SVM, SVR, dan GeoAI untuk penyakit menular yang telah dikerjakan sebelumnya oleh peneliti yang lain.

BAB III. METODOLOGI PENELITIAN

Dalam Bab ini disampaikan metodologi yang peneliti gunakan dalam mencapai tujuan penelitian. Kemudian disampaikan juga tahapan-tahapan dalam metodologi yang digunakan.

BAB IV. HASIL dan PEMBAHASAN

Dalam Bab ini menyajikan hasil eksperimen, analisis performa model, serta interpretasi hasil prediksi. Hasil analisis performa model SVM, SVR dan GeoAI untuk prediksi DBD dibahas secara komprehensif, termasuk evaluasi akurasi, kelebihan, dan keterbatasan model dalam konteks data yang digunakan.

BAB V. PENUTUP

Bagian ini merangkum temuan utama penelitian, yaitu sejauh mana model SVM dan GeoAI efektif dalam memprediksi wilayah endemis DBD, serta bagaimana variabel iklim mempengaruhi prediksi tersebut. Saran untuk penelitian lanjutan juga disertakan untuk memperbaiki model dan memperluas cakupan penelitian.

DAFTAR PUSTAKA

- [1] C. U. Nyenke, B. A. Nnokam, R. K. Esiere, and R. Nwalozie, “Dengue Fever: Etiology, Diagnosis, Prevention and Treatment,” *Asian Journal of Research in Infectious Diseases*, vol. 14, no. 1, pp. 26–33, Jul. 2023, doi: 10.9734/AJRID/2023/V14I1279.
- [2] A. V. Zende, Y. A. Shinde, R. R. Sonwalkar, and P. B. Parekar, “A Comprehensive Review Article on Dengue Fever,” *South Asian Research Journal of Pharmaceutical Sciences*, vol. 6, no. 03, pp. 89–105, Jun. 2024, doi: 10.36346/SARJPS.2024.V06I03.007.
- [3] A. Otu, B. Ebenso, A. Etokidem, and O. Chukwuekezie, “Dengue fever – an update review and implications for nigeria, and similar countries,” *Afr Health Sci*, vol. 19, no. 2, pp. 2000–2007, 2019, doi: 10.4314/AHS.V19I2.23.
- [4] K. S. Lee *et al.*, “Dengue virus surveillance in Singapore reveals high viral diversity through multiple introductions and in situ evolution,” *Infection, Genetics and Evolution*, vol. 12, no. 1, pp. 77–85, Jan. 2012, doi: 10.1016/J.MEEGID.2011.10.012.
- [5] C.-Y. Pan *et al.*, “Epidemiological Analysis of the Kaohsiung City Strategy for Dengue Fever Quarantine and Epidemic Prevention,” *BMC Infect Dis*, vol. 20, no. 1, 2020, doi: 10.1186/s12879-020-4942-y.
- [6] A. Adde *et al.*, “Predicting Dengue Fever Outbreaks in French Guiana Using Climate Indicators,” *PLoS Negl Trop Dis*, vol. 10, no. 4, p. e0004681, 2016, doi: 10.1371/journal.pntd.0004681.
- [7] N. Tian *et al.*, “Dengue Incidence Trends and Its Burden in Major Endemic Regions From 1990 to 2019,” *Trop Med Infect Dis*, vol. 7, no. 8, p. 180, 2022, doi: 10.3390/tropicalmed7080180.
- [8] B. K. Acharya, C. Cao, M. Xu, L. Khanal, S. Naeem, and S. Pandit, “Present and Future of Dengue Fever in Nepal: Mapping Climatic Suitability by Ecological Niche Model,” *Int J Environ Res Public Health*, vol. 15, no. 2, p. 187, 2018, doi: 10.3390/ijerph15020187.
- [9] B. Sahan, S. Tatlipinar, D. Marangoz, and F. Çiftçi, “Fundus Findings in Dengue Fever: A Case Report,” *Turk J Ophthalmol*, vol. 45, no. 5, pp. 223–225, 2015, doi: 10.4274/tjo.35761.
- [10] M. M. F. de Oliveira *et al.*, “Multivariate Analysis of Extreme Physical, Biological and Chemical Patterns in the Dynamics of Aquatic Ecosystem,” *J Environ Prot (Irvine, Calif)*, vol. 6, no. 8, pp. 885–901, Aug. 2015, doi: 10.4236/JEP.2015.68080.
- [11] N. A. Salim *et al.*, “Prediction of Dengue Outbreak in Selangor Malaysia Using Machine Learning Techniques,” *Sci Rep*, vol. 11, no. 1, 2021, doi: 10.1038/s41598-020-79193-2.
- [12] S. Halim, F. Felecia, and T. Octavia, “Statistical Learning for Predicting Dengue Fever Rate in Surabaya,” *Jurnal Teknik Industri*, vol. 22, no. 1, pp. 37–46, 2020, doi: 10.9744/jti.22.1.37-46.
- [13] Y.-H. Lai, “The Climatic Factors Affecting Dengue Fever Outbreaks in Southern Taiwan: An Application of Symbolic Data Analysis,” *Biomed Eng Online*, vol. 17, no. S2, 2018, doi: 10.1186/s12938-018-0575-4.

- [14] H. Harapan, A. Michie, M. Mudatsir, R. T. Sasmono, and A. Imrie, "Epidemiology of Dengue Hemorrhagic Fever in Indonesia: Analysis of Five Decades Data From the National Disease Surveillance," *BMC Res Notes*, vol. 12, no. 1, 2019, doi: 10.1186/s13104-019-4379-9.
- [15] R. P. Khetan *et al.*, "Profile of the 2016 Dengue Outbreak in Nepal," *BMC Res Notes*, vol. 11, no. 1, 2018, doi: 10.1186/s13104-018-3514-3.
- [16] A. E. Laureano-Rosario *et al.*, "Application of Artificial Neural Networks for Dengue Fever Outbreak Predictions in the Northwest Coast of Yucatan, Mexico and San Juan, Puerto Rico," *Trop Med Infect Dis*, vol. 3, no. 1, p. 5, 2018, doi: 10.3390/tropicalmed3010005.
- [17] C. Lin and T. Wen, "Using Geographically Weighted Regression (GWR) to Explore Spatial Varying Relationships of Immature Mosquitoes and Human Densities With the Incidence of Dengue," *Int J Environ Res Public Health*, vol. 8, no. 7, pp. 2798–2815, 2011, doi: 10.3390/ijerph8072798.
- [18] W. A. Abualamah, H. Banni, H. Almasmoum, Y. A. Allohibi, H. M. Samarin, and M. Bafail, "Determining Risk Factors for Dengue Fever Severity in Jeddah City, a Case-Control Study (2017)," *Pol J Microbiol*, vol. 69, no. 3, pp. 331–337, 2020, doi: 10.33073/pjm-2020-036.
- [19] F. Y. Nejad and K. D. Varathan, "Identification of Significant Climatic Risk Factors and Machine Learning Models in Dengue Outbreak Prediction," 2019, doi: 10.21203/rs.2.15755/v1.
- [20] Y.-T. Tseng and F.-S. Chang, "Re-Model the Relation of Vector Indices, Meteorological Factors and Dengue Fever," *J Trop Dis*, vol. 04, no. 02, 2016, doi: 10.4172/2329-891x.1000200.
- [21] C. Cortes, V. Vapnik, and L. Saitta, "Support-vector networks," *Machine Learning* 1995 20:3, vol. 20, no. 3, pp. 273–297, Sep. 1995, doi: 10.1007/BF00994018.
- [22] D. M. Abdullah and A. M. Abdulazeez, "Machine Learning Applications Based on SVM Classification a Review," *Qubahan Academic Journal*, vol. 1, no. 2, pp. 81–90, 2021, doi: 10.48161/qaj.v1n2a50.
- [23] A. Abdiansah and R. Wardoyo, "Time Complexity Analysis of Support Vector Machines (SVM) in LibSVM," *Int J Comput Appl*, vol. 128, no. 3, pp. 28–34, 2015, doi: 10.5120/ijca2015906480.
- [24] C. Butnariu, C. Lisa, F. Leon, and S. Curteanu, "Prediction of Liquid-crystalline Property Using Support Vector Machine Classification," *J Chemom*, vol. 27, no. 7–8, pp. 179–188, 2013, doi: 10.1002/cem.2508.
- [25] A. A. Besalatpour, S. Ayoubi, M. A. Hajabbasi, A. Yousefian-Jazi, and A. Gharipour, "Feature Selection Using Parallel Genetic Algorithm for the Prediction of Geometric Mean Diameter of Soil Aggregates by Machine Learning Methods," *Arid Land Research and Management*, vol. 28, no. 4, pp. 383–394, 2014, doi: 10.1080/15324982.2013.871599.
- [26] S. Ding and B. Qi, "Research of Granular Support Vector Machine," *Artif Intell Rev*, vol. 38, no. 1, pp. 1–7, 2011, doi: 10.1007/s10462-011-9235-9.
- [27] S. Ding and H. Huang, "Research on Parameters Optimisation of SVM Based on Swarm Intelligence," *International Journal of Collaborative Intelligence*, vol. 1, no. 1, p. 4, 2014, doi: 10.1504/ijci.2014.064852.
- [28] P. Shi, S. Ray, Q. Zhu, and M. A. Kon, "Top Scoring Pairs for Feature Selection in Machine Learning and Applications to Cancer Outcome

- Prediction," *BMC Bioinformatics*, vol. 12, no. 1, 2011, doi: 10.1186/1471-2105-12-375.
- [29] M. A. Cano Lengua and E. A. Papa Quiroz, "A Systematic Literature Review on Support Vector Machines Applied to Classification," *Proceedings of the 2020 IEEE Engineering International Research Conference, EIRCON 2020*, Oct. 2020, doi: 10.1109/EIRCON51178.2020.9254028.
- [30] N. I. Nordin, N. Mohd Sobri, N. A. Ismail, S. N. Zulkifli, N. F. Abd Razak, and M. Mahmud, "The Classification Performance using Support Vector Machine for Endemic Dengue Cases," *J Phys Conf Ser*, vol. 1496, no. 1, p. 012006, Mar. 2020, doi: 10.1088/1742-6596/1496/1/012006.
- [31] Y. Xu, Z. Yang, and X. Pan, "A novel twin support-vector machine with pinball loss," *IEEE Trans Neural Netw Learn Syst*, vol. 28, no. 2, pp. 359–370, Feb. 2017, doi: 10.1109/TNNLS.2015.2513006.
- [32] X. Huang, L. Shi, and J. A. K. Suykens, "Support vector machine classifier with pinball loss," *IEEE Trans Pattern Anal Mach Intell*, vol. 36, no. 5, pp. 984–997, 2014, doi: 10.1109/TPAMI.2013.178.
- [33] G. L. Grinblat, L. C. Uzal, P. F. Verdes, and P. M. Granitto, "Nonstationary Regression With Support Vector Machines," *Neural Comput Appl*, vol. 26, no. 3, pp. 641–649, 2014, doi: 10.1007/s00521-014-1742-6.
- [34] T. Miyao, K. Funatsu, and J. Bajorath, "Exploring Alternative Strategies for the Identification of Potent Compounds Using Support Vector Machine and Regression Modeling," *J Chem Inf Model*, vol. 59, no. 3, pp. 983–992, 2018, doi: 10.1021/acs.jcim.8b00584.
- [35] C. Wu, H. Yao, J. Du, and J. L. Jiang, "Research on Parameter Selection of Support Vector Regression," *Applied Mechanics and Materials*, vol. 344, pp. 219–225, 2013, doi: 10.4028/www.scientific.net/amm.344.219.
- [36] Y. Forghani, H. S. Yazdi, and S. Effati, "Support Vector Regression With Fuzzy Target Output," 2011, doi: 10.1109/iccke.2011.6413324.
- [37] W. Cao, X. Liu, and J. Ni, "Parameter Optimization of Support Vector Regression Using Henry Gas Solubility Optimization Algorithm," *Ieee Access*, vol. 8, pp. 88633–88642, 2020, doi: 10.1109/access.2020.2993267.
- [38] X. Fang, "Forest Coverage Prediction Based on Least Squares Support Vector Regression Algorithm," *Adv Mat Res*, vol. 446–449, pp. 2978–2982, 2012, doi: 10.4028/www.scientific.net/amr.446-449.2978.
- [39] J. Shim, K. Seok, C.-S. Hwang, and D. Cho, "Support Vector Quantile Regression Using Asymmetric E-Insensitive Loss Function," *Commun Stat Appl Methods*, vol. 18, no. 2, pp. 165–170, 2011, doi: 10.5351/ckss.2011.18.2.165.
- [40] A. Arjmandzadeh, S. Effati, and M. Zamirian, "Interval Support Vector Machine in Regression Analysis," *Journal of Mathematics and Computer Science*, vol. 02, no. 03, pp. 565–571, 2011, doi: 10.22436/jmcs.02.03.19.
- [41] H. Tamai *et al.*, "Prediction of Sustained Response to Low-dose Pegylated Interferon Alpha-2b Plus Ribavirin in Patients With Genotype 1b and High Hepatitis C Virus Level Using Viral Reduction Within 2 weeks After Therapy Initiation," *Hepatology Research*, vol. 41, no. 12, pp. 1137–1144, 2011, doi: 10.1111/j.1872-034x.2011.00879.x.

- [42] X. Meng, C. Cai, Y. Wang, Q. Wang, and T. Liu, “Remaining Useful Life Prediction of Lithium-Ion Batteries Using CEEMDAN and WOA-SVR Model,” *Front Energy Res*, vol. 10, 2022, doi: 10.3389/fenrg.2022.984991.
- [43] D. Phung *et al.*, “Identification of the prediction model for dengue incidence in Can Tho city, a Mekong Delta area in Vietnam,” *Acta Trop*, vol. 141, no. Pt A, pp. 88–96, Jan. 2015, doi: 10.1016/J.ACTATROPICA.2014.10.005.
- [44] A. J. Smola and B. Schölkopf, “A tutorial on support vector regression,” *Stat Comput*, vol. 14, no. 3, pp. 199–222, Aug. 2004, doi: 10.1023/B:STCO.0000035301.49549.88/METRICS.
- [45] D. Murakami, “Adaptively Robust Geographically Weighted Regression,” 2021, doi: 10.48550/arxiv.2106.15811.
- [46] R. G. Tsiko, “Geographically Weighted Regression of Determinants Affecting Women’s Access to Land in Africa,” *Geosciences (Basel)*, vol. 6, no. 1, p. 16, 2016, doi: 10.3390/geosciences6010016.
- [47] T. Nakaya, A. S. Fotheringham, C. Brunsdon, and M. Charlton, “Geographically Weighted Poisson Regression for Disease Association Mapping,” *Stat Med*, vol. 24, no. 17, pp. 2695–2717, 2005, doi: 10.1002/sim.2129.
- [48] M. Fathurahman, P. Purhadi, S. Sutikno, and V. Ratnasari, “Geographically Weighted Multivariate Logistic Regression Model and Its Application,” *Abstract and Applied Analysis*, vol. 2020, pp. 1–10, 2020, doi: 10.1155/2020/8353481.
- [49] A. S. Ghareb, M. H. Afif, A.-R. Hedar, T. H. A. Hamid, and A. Saif, “Enhanced Support Vector Machine Based on Metaheuristic Search for Multiclass Problems,” *Journal of Computer Science*, vol. 16, no. 7, pp. 871–885, 2020, doi: 10.3844/jcssp.2020.871.885.
- [50] W. Li and C. Y. Hsu, “GeoAI for Large-Scale Image Analysis and Machine Vision: Recent Progress of Artificial Intelligence in Geography,” *ISPRS Int J Geoinf*, vol. 11, no. 7, p. 385, 2022, doi: 10.3390/ijgi11070385.
- [51] J. L. Arthur, “Rethinking Geographic Thought in the Digital Space; A Review of the Arguments for Sustainability and Resilience,” 2023, doi: 10.21203/rs.3.rs-3644702/v1.
- [52] B. Hosen, “Leveraging Artificial Intelligence and Big Data for Advanced Spatial Analytics and Decision Support Systems in Geography,” *Malays. Apd. Geog.*, vol. 1, no. 2, pp. 62–67, 2023, doi: 10.26480/magg.02.2023.62.67.
- [53] G. Bordogna and C. Fugazza, “Artificial Intelligence for Multisource Geospatial Information,” *ISPRS Int J Geoinf*, vol. 12, no. 1, p. 10, 2022, doi: 10.3390/ijgi12010010.
- [54] F. S. Hosseini, “Geospatial Artificial Intelligence (GeoAI) and Satellite Imagery Fusion for Soil Physical Property Predicting,” *Sustainability*, vol. 15, no. 19, p. 14125, 2023, doi: 10.3390/su151914125.
- [55] A. L. A. Navas, F. Osei, R. J. S. Magalhães, L. Leonardo, and A. Stein, “Modelling the Impact of MAUP on Environmental Drivers for Schistosoma Japonicum Prevalence,” *Parasit Vectors*, vol. 13, no. 1, 2020, doi: 10.1186/s13071-020-3987-5.

- [56] A. Amponsah, “Utilization of GeoAI Applications in the Health Sector: A Review,” *J. Health. Science. Med. Therapy.*, vol. 1, no. 02, pp. 49–60, 2023, doi: 10.59653/jhsmt.v1i02.240.
- [57] A. M. Zaidan, “The Leading Global Health Challenges in the Artificial Intelligence Era,” *Front Public Health*, vol. 11, 2023, doi: 10.3389/fpubh.2023.1328918.
- [58] P. Liu and F. Biljecki, “A review of spatially-explicit GeoAI applications in Urban Geography,” *International Journal of Applied Earth Observation and Geoinformation*, vol. 112, p. 102936, Aug. 2022, doi: 10.1016/J.JAG.2022.102936.
- [59] S. Pertuack, “Geographic Artificial Intelligence and Unmanned Aerial Vehicles Application for Correlation Analysis of Settlement Density and Land Surface Temperature in Panggang Island Jakarta,” *Buana J. Geografi Ekologi Dan Kebencanaan*, vol. 1, no. 1, pp. 39–47, 2023, doi: 10.56211/buana.v1i1.340.
- [60] G. Kim, “Development of GeoAI-based Environmental Policy Establishment Support System : Analysis of the Relationship Between Land Cover and LST in Seoul,” *Journal of Climate Change Research*, vol. 13, no. 6, pp. 859–867, 2022, doi: 10.15531/ksccr.2022.13.6.859.
- [61] T. P. Dao *et al.*, “A Geospatial Platform to Support Visualization, Analysis, and Prediction of Tuberculosis Notification in Space and Time,” *Front Public Health*, vol. 10, 2022, doi: 10.3389/fpubh.2022.973362.
- [62] T. VoPham, J. E. Hart, F. Laden, and Y. Chiang, “Emerging Trends in Geospatial Artificial Intelligence (geoAI): Potential Applications for Environmental Epidemiology,” *Environmental Health*, vol. 17, no. 1, 2018, doi: 10.1186/s12940-018-0386-x.
- [63] W. Gao, “A Two-Stage Prediction Filling Method With Support Vector Technologies Optimized Competitively in Stages by Grey Wolf Optimizer and Particle Swarm Optimization for Missing Fasting Blood Glucose,” *Proc Inst Mech Eng H*, vol. 237, no. 12, pp. 1427–1440, 2023, doi: 10.1177/09544119231206456.
- [64] J. Balfer and J. Bajorath, “Systematic Artifacts in Support Vector Regression-Based Compound Potency Prediction Revealed by Statistical and Activity Landscape Analysis,” *PLoS One*, vol. 10, no. 3, p. e0119301, 2015, doi: 10.1371/journal.pone.0119301.
- [65] R. Rodríguez-Pérez, M. Vogt, and J. Bajorath, “Support Vector Machine Classification and Regression Prioritize Different Structural Features for Binary Compound Activity and Potency Value Prediction,” *ACS Omega*, vol. 2, no. 10, pp. 6371–6379, 2017, doi: 10.1021/acsomega.7b01079.
- [66] D. Nurwaha, “Comparison of Kernel Functions of Support Vector Machines: A Case Study for the Solar Cell Output Power Prediction,” *International Journal of Energy Applications and Technologies*, vol. 7, no. 1, pp. 1–6, 2020, doi: 10.31593/ijeat.630789.
- [67] S. Gao, “A Review of Recent Researches and Reflections on Geospatial Artificial Intelligence,” *Wuhan Daxue Xuebao (Xinxix Kexue Ban)/Geomatics and Information Science of Wuhan University*, vol. 45, no. 12, pp. 1865–1874, 2020, doi: 10.13203/j.whugis20200597.

- [68] A. Lisowska and I. Rekik, “Predicting Emotional Intelligence Scores From Multi-Session Functional Brain Connectomes,” pp. 103–111, 2018, doi: 10.1007/978-3-030-00320-3_13.
- [69] “Confusion Matrix in Machine Learning - GeeksforGeeks.” Accessed: Jul. 01, 2023. [Online]. Available: <https://www.geeksforgeeks.org/confusion-matrix-machine-learning/>
- [70] F. Demir, “Deep autoencoder-based automated brain tumor detection from MRI data,” *Artificial Intelligence-Based Brain-Computer Interface*, pp. 317–351, Jan. 2022, doi: 10.1016/B978-0-323-91197-9.00013-8.
- [71] W. Shao, H. Sun, Y. Wang, and X. Qing, “A multi-level damage classification technique of aircraft plate structures using Lamb wave-based deep transfer learning network,” *Smart Mater Struct*, vol. 31, no. 7, p. 075019, Jun. 2022, doi: 10.1088/1361-665X/AC726F.
- [72] “(PDF) Optimizing F-Measure with Support Vector Machines.” Accessed: Jul. 11, 2023. [Online]. Available: https://www.researchgate.net/publication/2856823_Optimizing_F-Measure_with_Support_Vector_Machines
- [73] “Choosing Performance Metrics. Accuracy, recall, precision, F1 score—... | by S. T. Lanier | Towards Data Science.” Accessed: Jul. 01, 2023. [Online]. Available: <https://towardsdatascience.com/choosing-performance-metrics-61b40819eae1>
- [74] I. Salam *et al.*, “Modeling Dynamic System for Prediction of Dengue Hemorrhagic Fever in Maros District,” *Open Access Maced J Med Sci*, vol. 9, no. E, pp. 901–905, 2021, doi: 10.3889/oamjms.2021.7098.
- [75] V.-H. Nguyen *et al.*, “Deep Learning Models for Forecasting Dengue Fever Based on Climate Data in Vietnam,” *PLoS Negl Trop Dis*, vol. 16, no. 6, p. e0010509, 2022, doi: 10.1371/journal.pntd.0010509.
- [76] K. Shaukat and S. M. U. Azmeen, “Dengue Fever Prediction: A Data Mining Problem,” *J Data Mining Genomics Proteomics*, vol. 06, no. 03, 2015, doi: 10.4172/2153-0602.1000181.
- [77] U. Haque *et al.*, “Spatial prediction of malaria prevalence in an endemic area of Bangladesh,” *Malar J*, vol. 9, no. 1, pp. 1–10, May 2010, doi: 10.1186/1475-2875-9-120/FIGURES/4.
- [78] F. Fahmi, A. P. Pasaribu, M. Theodora, and K. Wangdi, “Spatial analysis to evaluate risk of malaria in Northern Sumatera, Indonesia,” *Malar J*, vol. 21, no. 1, pp. 1–12, Dec. 2022, doi: 10.1186/S12936-022-04262-Y/TABLES/3.
- [79] A.-K. Iddrisu and Y. A. Amoako, “Spatial Modeling and Mapping of Tuberculosis Using Bayesian Hierarchical Approaches,” *Open J Stat*, vol. 06, no. 03, pp. 482–513, 2016, doi: 10.4236/OJS.2016.63043.
- [80] A. Q. N. Mylne *et al.*, “Mapping the zoonotic niche of Lassa fever in Africa,” *Trans R Soc Trop Med Hyg*, vol. 109, no. 8, pp. 483–492, Aug. 2015, doi: 10.1093/TRSTMH/TRV047.
- [81] F. H. Nanzaluka *et al.*, “Risk Factors for Epidemic Cholera in Lusaka, Zambia—2017,” *Am J Trop Med Hyg*, vol. 103, no. 2, p. 646, Aug. 2020, doi: 10.4269/AJTMH.20-0089.
- [82] M. S. Rahman *et al.*, “Mapping the spatial distribution of the dengue vector *Aedes aegypti* and predicting its abundance in northeastern Thailand using

- machine-learning approach,” *One Health*, vol. 13, Dec. 2021, doi: 10.1016/J.ONEHLT.2021.100358.
- [83] I. N. Tanawi, V. Vito, D. Sarwinda, H. Tasman, and G. F. Hertono, “Support Vector Regression for Predicting the Number of Dengue Incidents in DKI Jakarta,” *Procedia Comput Sci*, vol. 179, pp. 747–753, 2021, doi: 10.1016/J.PROCS.2021.01.063.
- [84] S. Peng, L. Bai, L. Xiong, Q. Qu, X. Xie, and W. Shulin, “GeoAI-based Epidemic Control With Geo-Social Data Sharing on Blockchain,” 2021, doi: 10.1109/healthcom49281.2021.9399031.
- [85] I. Made, Y. A. Dala, I. Ketut, G. Darma Putra, and P. Wira Buana, “Forecasting Cases of Dengue Hemorrhagic Fever Using the Backpropagation, Gaussians and Support-Vector Machine Methods,” *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 5, no. 2, pp. 335–341, Apr. 2021, doi: 10.29207/RESTI.V5I2.2936.
- [86] M. Nabilah, R. Tyasnurita, F. Mahananto, W. Anggraeni, R. A. Vinarti, and A. Muklason, “Forecasting the number of dengue fever based on weather conditions using ensemble forecasting method,” *IAES International Journal of Artificial Intelligence*, vol. 12, no. 1, pp. 496–496, Mar. 2023, doi: 10.11591/IJAI.V12.I1.PP496-504.
- [87] M. Mistawati, Y. Yasnani, and H. Lestari, “Forecasting prevalence of dengue hemorrhagic fever using ARIMA model in Sulawesi Tenggara Province, Indonesia,” *Public Health of Indonesia*, vol. 7, no. 2, pp. 75–86, Jun. 2021, doi: 10.36685/PHI.V7I2.411.
- [88] A. Siddiq, N. Shukla, and B. Pradhan, “Spatio-temporal modelling of dengue fever cases in Saudi Arabia using socio-economic, climatic and environmental factors,” *Geocarto Int*, vol. 37, no. 26, pp. 12867–12891, 2022, doi: 10.1080/10106049.2022.2072005.
- [89] S. K. Dey *et al.*, “Prediction of dengue incidents using hospitalized patients, metrological and socioeconomic data in Bangladesh: A machine learning approach,” *PLoS One*, vol. 17, no. 7 July, Jul. 2022, doi: 10.1371/journal.pone.0270933.
- [90] K. Dalam Terbitan, K. R. Kesehatan, and I. P. Direktorat Jenderal Pengendalian Penyakit Dan Penyehatan Lingkungan Kementerian Kesehatan RI, “Pedoman Pencegahan dan Pengendalian Demam Berdarah Dengue di Indonesia”, 2017.